

مانیتورینگ ارتعاشات و تشخیص هوشمند خطا در بیرینگ ها با استفاده از کلاسیفایر **Multi Class SVM** به همراه معرفی ویژگی های تاثیر گذار سیگنال ارتعاش

امین کرمی

نیروگاه اتمی بوشهر، A.Karami.oce@gmail.com

چکیده

طراحی های نوین صنعتی با هدف افزایش سرعت و سطح تولیدات، موجب گسترش استفاده از بیرینگها در صنایع گردید. از سوی دیگر با استفاده بیشتر از بیرینگها، بزرگترین چالش فنی پیش رو شناسایی عیوب این قطعات پیش از آسیب های جدی می باشد. در این مقاله با طراحی یک سیستم مبتنی بر کلاسیفایر ماشین بردار پشتیبان چند کلاسه (**Multi Class SVM**) ضمن شناسایی به موقع عیوب ایجاد شده در بیرینگها، در صورت امکان نوع آن نیز مشخص گردد. با انتخاب روش **Signal base** به عنوان یکی از روش های بررسی شرایط کاری و طرح سؤال اصلی چگونگی تشخیص خطای بیرینگها بصورت هوشمند، ۲۸۰ نمونه سیگنال ارتعاش از ۴ وضعیت بیرینگ در آزمایشگاه استخراج شد و سپس ویژگی های مختلف این سیگنال ها مورد تجزیه و تحلیل قرار گرفت. نتایج حاصل نشان دهنده توانایی کلاسیفایر انتخاب شده و تاثیر ویژگی های انتخابی در تشخیص هوشمند خطای بیرینگ ها می باشد. **واژه های کلیدی:** مانیتورینگ ارتعاش، تشخیص هوشمند خطا، کلاسیفایر **Multi Class SVM**.

۱- مقدمه

مشخصه های سیستم از رفتار قابل قبول، معمولی یا استاندارد دانست. بنابراین، وقوع خطا در یک زیر سیستم، عموماً موجب ایجاد تغییر در راندمان کل سیستم می گردد. مساله دیگری که برای سیستم های کنترلی مورد توجه قرار می گیرد، **Failure** یا شکست سیستم می باشد. **Fault** سیستم را از حالت بازده قابل قبول به بازده پایین می برد، اما **Failure** سیستم را از بازده پایین یا غیر قابل قبول به منطقه خطر وارد می سازد. یکی از وظایف اصلی سیستم تشخیص خطا، جلوگیری از تبدیل شدن **Fault** به **Failure** می باشد. [1]

با توجه به تعریف خطا و شکست، در صورت وقوع خطا در سیستم، اگر عملیات تشخیص به درستی صورت نگیرد، امکان تبدیل شدن آن به شکست وجود دارد، به همین منظور اپراتورها در صنایع با گذر زمان جای خود را به سیستم های هوشمند تشخیص خطا می دهند.

در سال های اخیر با ابداع روش های خودکار شناسایی عیب، پیشرفت سریعی در زمینه بررسی شرایط کاری ماشین ها، ایجاد شده است. هدف تحقیقات جدید، بدست آوردن روش های دسته بندی ایست که این سیگنال ها را در دسته هایی که هر کدام نشان دهنده یک نوع عیب می باشد، قرار دهند. روش های مختلفی برای تشخیص وقوع عیب و شناسایی نوع عیب و اندازه پیش رفتگی آن مطرح شده که با گذشت زمان قابلیت آنها افزوده شده و این روش ها جایگزین اپراتورها شده اند. آشنایی با انواع خطا پیش نیاز استفاده از روش های تشخیص خطا می باشد.

در حالت کلی، **Fault** چیزی است که رفتار سیستم را تغییر می دهد به نحوی که سیستم دیگر مقصود مورد نظر را برآورده نکند. **Fault** را می توان انحراف حداقل یکی از

در این معانه سعی شده است تا با معرفی حصاهای رایج در بیرینگ ها و در کنار آن سیگنال های ارتعاش یافته توسط این خطا ها در سطح بیرینگ، یک سیستم هوشمند تشخیص خطا طراحی گردد تا بتواند در کنار شناسایی فرکانس های خطا (پیش از تبدیل شدن آنها به شکست)، نوع خطا را نیز مشخص نماید. این توانمندی به طور یقین باعث کاهش دوره تعمیرات نیز خواهد گردید.

۲- بیرینگ ها

بیرینگ های غلتشی از جمله اجزاء با عمر کاری محدود ماشین ها به شمار می آیند و بنابراین جزء اقلام پرمصرف محسوب می گردند. نیاز به آنها زیاد و طول عمر مفید کاری آنها با در نظر گرفتن یک سری از عوامل اثر گذار کاهش می یابد. جدول ۱ نشان دهنده عوامل موثر بر کاهش طول عمر مفید کاری یک بیرینگ می باشد.

جدول ۱: عوامل موثر و تاثیرات آنها بر عمر کاری بیرینگ ها. [19]

عامل	اثر حاصل
ساخت	هموژن نبودن مواد تولرانسهای ساخت
حمل و نقل و انبارش	بسته بندی نامناسب ارتعاش تغییر شکل
کارکرد	بارگذاری اولیه نادرست تولرانس هندسی خطاهای هم محوری بارگذاری بیش از حد روانکاری نادرست ذرات خارجی (کثافت) واسطه های خارجی (گازهای خورنده) رطوبت داغ شدن بیش از حد

عیوب در بیرینگ های غلتشی ناشی از جدا شدن موضعی مواد، ترک های ناشی از خستگی روی سطوح تماس در بیرینگ، خرد شدن یا ترک برداشتن اجزاء غلتشی می باشند. بر اثر تغییر در ساختمان هندسی بیرینگ، زمانی که سطوح آسیب دیده با هم درگیر می شوند، باعث تولید ضربه هایی می شوند. حاصل این ضربه ها، تولید امواج ارتعاشی و صوتی است که از طریق حلقه بیرونی و محفظه بیرینگ به بیرون منتشر می شوند. بعضی اوقات به این ضربه ها ضربه های لحظه ای یا شوک^۱ پالس می گویند. شوک پالس های حاصل از بیرینگ معیوب با پیروید بسیار کوچک و میزان صعود سریع آنها در مقایسه با زمان تکرار شوک ها، مشخص می شوند. پیروید شوک پالس ها در مقایسه با فاصله بین دو پالس بسیار کوچک است. [17]

هر یک از خطاهای بوجود آمده در بیرینگ منتشر کننده و یا تشدید کننده شوک پالس ویژه ای می باشد.

خطاهای رایج در بیرینگ ها شامل موارد ذیل می باشند:

- Scratch on Outer Race
- Scratch on Inner Race

1- Shock

با داشتن مثالهای آموزشی (x_i, y_i) که $i=1,2,\dots,N$;

$$y_i \in \{+1, -1\} \text{ Minimise } \|w\|^2$$

$$\text{Subject to } y_i \langle w, x_i \rangle + b \geq 1 \text{ for all } i \quad (2)$$

$$\text{Note that } \|w\|^2 = w^T w$$

این یک مسئله quadratic programming با محدودیت هایی بصورت نامعادلات خطی است. روشهای شناخته شده ای برای چنین مسئله هایی بوجود آمده اند.

برای برطرف کردن مشکل تفکیک ناپذیری داده ها، از روش C-SVM استفاده می شود که در آن مفهوم ابرصفحه جداکننده بهینه کلی تر شده، بگونه ای که جواب مسئله از طریق مینیمم کردن تابعی که ترکیبی از دو ضابطه می باشد بدست می آید. این دو ضابطه عبارتند از: ماکزیمم کردن حاشیه (مانند حالت داده هایی با تفکیک پذیری خطی) و مینیمم کردن خطا (برای تعریف جریمه به نمونه های با طبقه بندی اشتباه). تابع جدید بصورت زیر تعریف می شود: [20]

$$\Psi(W, \xi) = \frac{1}{2} \|W\|^2 + C \sum_{i=1}^N \xi_i \quad (3)$$

یک راه حل این است که اندکی کوتاه آمده و مقداری خطا در دسته بندی را بپذیریم!

این کار با معرفی متغیر ξ_i انجام می شود که نشانگر تعداد نمونه هایی است که توسط تابع $w^T x + b$ غلط ارزیابی می شوند.

با معرفی متغیر $\xi_i, i=1, 2, \dots, N$ محدودیت های قبلی ساده تر شده و رابطه

$$y_i \langle w, x_i \rangle + b \geq 1 - \xi_i \quad (4)$$

بصورت زیر تغییر می کند:

$$x_i, \xi_i \geq 0 - y_i \langle w, x_i \rangle + b \geq 1 - \xi_i \quad (5)$$

در این مقاله به جهت نمونه برداری و تهیه داده های آزمایشگاهی چهار وضعیت یک بیرینگ در آزمایشگاه مورد سنجش قرار گرفت. در وضعیت اول یک بیرینگ سالم (NB) بر روی شفت موتور الکتریکی با دور ثابت ۱۴۰۰ دور بر دقیقه نصب گردید و از سوئی دیگر بر روی آن باری به وزن ۵۰۰ گرم نصب گردید. با افزایش بار موتور به صورت وزنه های ۱۰۰ گرمی (از ۵۰۰ گرم تا ۷۵۰۰ گرم) بوسیله سنسور ارتعاش سنجی تعبیه شده در یاتاقان بیرینگ، ارتعاشات موتور نمونه برداری شد بدین صورت ۷۰ نمونه از ارتعاشات یک بیرینگ سالم در دور ثابت ۱۴۰۰ دور بر دقیقه فراهم گردید. در وضعیت دوم بیرینگی مشابه از فقط با خراشیدگی بر روی حلقه خارجی (ORD) جایگزین بیرینگ سالم شد و مراحل تکرار گردید. در وضعیت سوم بیرینگ با خراش بر روی حلقه داخلی (IRD) جایگزین گردید و در وضعیت چهارم بیرینگ با خراش بر روی لغزنده (BD) مورد استفاده قرار گرفت. در انتها ۲۸۰ نمونه سیگنال در چهار کلاس متفاوت از یک بیرینگ در وضعیت سالم و ۳ بیرینگ مشابه دیگر اما هر یک دارای خطایی مشخص فراهم گردید.

۳- انتخاب کلاسیفایر و ویژگی جهت پردازش سیگنال

SVM دسته بندی کننده ای است که جزو شاخه KernelMethods در یادگیری ماشین محسوب می شود. SVM اصولاً یک کلاسیفایر خطی است که ایده اصلی آن ایجاد یک فوق صفحه به عنوان سطح تصمیم گیرنده می باشد؛ به طوری که حد تفکیک بین نمونه ها حداکثر شود.

یک مسئله طبقه بندی با نظارت دو کلاسه را در نظر بگیرید. فرض کنید مجموعه داده های آموزشی شامل N بردار از فضای ویژگی m بعدی $x_i \in \mathcal{R}^m$ می باشد. به هر یک از بردارهای x یک برچسب $\{1, -1\}$ نسبت داده می شود که کلاس مربوط به داده x_i را نشان می دهد. تابع جداساز مربوط به ابر صفحه بهینه یک معادله وابسته به ضرایب لاگرانژ و نمونه های آموزشی است که مطابق رابطه زیر محاسبه می گردد:

$$f(x) = \text{sign} \left(\sum \alpha_i y_i \cdot (x \cdot x_i) + b \right) \quad (1)$$

در حالت ایده آل همه این متغیرها باید صفر باشند. [20]

در اینصورت مسئله بهینه سازی تبدیل میشود به یافتن w به نحوی که معادله زیر مینیمم شود:

(۶)

$$\frac{1}{2}\|w\|^2 + C\sum_i \xi_i^2$$

subject To

$$y_i(w^T x_i + b) \geq 1 - \xi_i, \quad \xi_i \geq 0, \quad \forall i$$

که در آن $C > 0$ می باشد. جمله اضافه شدن سعی دارد تا حد امکان همه متغیرهای slack را کوچک نماید.

ξ_i که متغیرهای slack نامیده می شوند برای محاسبه تفکیک ناپذیری داده ها مطرح شده و ثابت C یک پارامتر تنظیم کننده می باشد که امکان کنترل جریمه مربوط به خطاها را فراهم می کند. هر چقدر مقدار C بزرگتر باشد، جریمه تعلق گرفته به نمونه های با طبقه بندی اشتباه نیز بیشتر می شود. قیود تابع هدف به صورت زیر می باشند:

$$y_i(w \cdot x_i + b) \geq 1 - \xi_i, \quad i = 1, 2, \dots, N \quad (7)$$

$$\xi_i \geq 0, \quad i = 1, 2, \dots, N.$$

توجه شود که در حالت داده های ξ_i تفکیک ناپذیر ξ_i ، دو نوع support vector وجود دارد:

۱. Margin support vector که بر روی حاشیه ابر صفحه قرار می گیرد.
۲. Nonmargin support vector که در طرف اشتباه این حاشیه قرار دارد.

چنانچه برای حل مساله فوق از ضرایب لاگرانژ استفاده کنیم در این صورت شکل مساله ثانویه به شکل زیر تبدیل می شود:

$$\max_{\alpha \in \mathbb{R}^N} \text{imize} \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \quad (8)$$

$$\text{subject to: } \sum_{i=1}^N \alpha_i y_i = 0, 0 \leq \alpha_i \leq C, i = 1, 2, \dots, N$$

تنها فرق این حالت با حالت قبل این است که C به عنوان یک مرز بالایی برای ضرایب لاگرانژ عمل می کند. [20]

نوعی از توابع kernel، اجازه می دهند تا حل مساله ثانویه بطور قابل توجهی ساده شود. از آنجا که از محاسبه ضرب داخلی در فضای ترانسفر شده جلوگیری می کند، شکل مساله ثانویه که از تابع kernel استفاده می کند، برای C -SVM بصورت زیر خواهند بود.

$$\max_{\alpha \in \mathbb{R}^N} \text{imize} \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j K(x_i \cdot x_j) \quad (9)$$

$$\text{Subject to: } 0 \leq \alpha_i \leq C, i = 1, 2, \dots, N, \sum_{i=1}^N \alpha_i y_i = 0$$

نتیجه نهایی، یک تابع جداساز است که معمولاً تابعی از داده ها در فضای ویژگی اولیه با ابعاد کمتر است.

$$f(X) = \text{sign} \left(\sum_{i \in S} y_i \alpha_i \cdot K(X, X_i) + b \right) \quad (10)$$

شکل هندسی تابع جداساز مرتبط با نوع تابع kernel تغییر می کند. یک تابع kernel معروف که دارای شرایط Mercer می باشد تابع گوسی است که بصورت رابطه ذیل تعریف می شود.

$$K(X, X') = \exp \left(-\gamma \|X - X'\|^2 \right) \quad (11)$$

از آنجا که روش SVM برای طبقه بندی بین دو کلاس طراحی شده است، کلیه اطلاعات را با لیبل گذاری ± 1 به دو دسته مجزا تقسیم می نماید. SVM در واقع نوعی کاسیفایر باینری است و تحقیق در مورد چگونگی استفاده موثر از آن برای طبقه بندی چند کلاس ها هنوز در حال انجام می باشد.

تا به حال روش های مختلفی پیشنهاد شده است که در آن به طور معمول ما با ترکیب چند کاسیفایر باینری یک کاسیفایر چند کلاسه در اختیار داریم. برخی از پژوهشگران نیز روشی را پیشنهاد می نمایند که در آن همه کلاس در یک مرحله در نظر گرفته شده است و از آن می توان به عنوان محاسبات حجیم برای حل مشکلات چند کلاسه ها نام برد. این روش با استفاده از مشکلات در مقیاس بزرگ به طور جدی انجام آزمایش نشده است. به خصوص برای روش

از مجموع ۲۸۰ نمونه موجود، ۲۴۰ نمونه جهت آموزش کلاسیفایر و تعداد ۶۰ نمونه باقیمانده نیز برای تست کردن کلاسیفایر بکار رفت.

همان طور که در بخش ۲ عنوان شد، خطاهای مختلف بوجود آمده در بیرینگها تأثیرات متفاوتی بر فرکانسهای ارتعاشات منتشر شده توسط بیرینگ میگذارد لذا به جهت تفکیک و تمایز آنها از یکدیگر نمی توان به سیگنال و یا تبدیلات حوزه فرکانس آن بسنده نمود. از همین رو از سیگنالهای اصلی تعداد ۱۲ ویژگی استخراج شد.

سپس Multi Class SVM با استفاده از ۱۲ ویژگی استخراج شده از سیگنالهای آموزشی (۲۴۰ داده نمونه)، آموزش داده شد و پس از آن عملکرد کلاسیفایر بر روی دادههای تست مشاهده شد.

تابع کرنل استفاده شده در این طراحی (کلاسیفایر Multi Class SVM و ویژگیهای سیگنال) کرنل گوسی با پارامتر گوسی ۰.۰۰۵ بوده و مقدار C نیز برابر ۵۰۰ در نظر گرفته شده است. در مرحله اول تجزیه و تحلیل، تمامی ۱۲ ویژگی استخراج شده از سیگنال ارتعاش مورد استفاده قرار گرفت. نتایج بدست آمده پس از اعمال سیگنالهای تست در ورودی کلاسیفایر طی جدول صحت درستی، در جدول ۳ ارائه شده است.

جدول ۳: خروجی کلاسیفایر با استفاده از همگی ویژگیهای سیگنال

	BD	ORD	IRD	NB
BD	۱۰	۱	۱	۳
ORD	۱	۱۱	۰	۳
IRD	۰	۲	۱۰	۳
NB	۰	۱	۰	۱۴

با توجه به نتایج بدست آمده از جدول ۳ مشخص شد، کلاسیفایر طراحی شده با استفاده از ۱۲ ویژگی دارای خطایی برابر با ۲۵ درصد می باشد.

در مرحله بعد با توجه به تأثیر متفاوت هر یک از ویژگیها بر نحوه کلاس بندی کلاسیفایر، بر آن شدیم تا با انتخاب بهترین ویژگیها میزان خطای تشخیص و دسته بندی را کاهش دهیم، لذا ویژگیها به صورت تک به تک انتخاب شد و تأثیر هر یک بر نحوه کلاس بندی مورد بررسی قرار گرفت. درصد خطای بدست آمده در خروجی در لحظه استفاده از

های حل Multi Class SVM در یک مرحله، یک مسئله بهینه سازی بسیار بزرگتر مورد نیاز است که تا به حال آزمایشات به مجموعه داده های کوچک محدود بوده است.

در مقاله ای از Chic-Wei Hsu و Chic-Jen Lin با پیاده سازی و تجزیه و تحلیل دو طبقه روشهایی با عنوان all-together ارائه شده است. سه روش مهم ارائه شده در این مقاله شامل روشهای ذیل می باشد:

۱- یک در برابر همه (One-against-all)

۲- یک در مقابل یک (One-against-one)

۳- DAGSVM


علاوه بر روشهای ذکر شده در بالا، روشهای دیگر برای پیاده سازی Multi Class SVM وجود دارد. در هر حال، با توجه به محدودیت در اینجا ما نمی توانیم بر روی همه روشها تجزیه و تحلیل ارائه نماییم. [10]

در این مقاله جهت بکاربری Multi Class SVM از روش یک در برابر همه استفاده شده است.

۴- تحلیل بر اساس داده های آزمایشگاهی

در اینجا برآنیم تا با استفاده از نتایج آزمایشگاهی و تحلیلهای صورت گرفته نشان دهیم کلاسیفایر پیشنهادی Multi Class SVM می تواند جهت تشخیص نوع خطا در بیرینگها مورد استفاده قرار گیرد و نتایج قابل قبولی ارائه نماید.

جهت معتبرسازی روش پیشنهادی، ۲۸۰ نمونه سیگنال از داده های ارتعاش حقیقی یاتاقان موتور، شامل ۴ کلاس ۱- داده های یاتاقان نرمال (NB)، ۲- داده های خراشیدگی بر روی حلقه خارجی (ORD)، ۳- داده های خراشیدگی بر روی حلقه داخلی (IRD) و ۴- داده های خراشیدگی بر روی لغزنده (BD) مورد استفاده قرار گرفت.



شکل: سیگنال استخراج شده به ترتیب NB, ORD, IRD, و BD

کلاسیفایر با یک ویژگی سیگنال در جدول ۴ ارائه شده است.

سوم به معرفی کلاسیفایر استفاده شده و نحوه عملکرد آن پرداخته شد.

با توجه به اهمیت انتخاب ویژگی‌های مناسب از بین ویژگی‌های استخراج شده، با بکار بری روش های PCA به عنوان روش انتخاب ویژگی تاثیر هر یک از ویژگی ها بر خطای خروجی سنجیده شد و بهترین ویژگی ها انتخاب گردیدند.

در بخش تجزیه و تحلیل نیز با طراحی یک کلاسیفایر Multi Class SVM و در نظر گرفتن ۴ حالت (۱ حالت سالم و سه خطا) عمده در بیرینگ‌ها و با درصد خطای قابل قبولی امکان تشخیص وقوع خطا و همچنین در کنار آن تشخیص نوع خطا حاصل شده است.

کلاسیفایر Multi Class SVM در مقایسه با روش های دیگری همچون تبدیلات فرکانس و تبدیل موجک و حتی نسبت به SVM دارای درصد خطای بسیار کمتری می‌باشد. البته این بهبود در نتایج به قیمت پیچیده‌تر شدن ساختار کلاسیفایر حاصل شده است. در واقع در این کلاسیفایر حجم محاسبات بسیار بیشتر از سایر روش ها می باشد.

جدول ۶: مقایسه روش های بکار رفته در مقاله

MEAN	GBR	IRD	ORD	BLD	Classifier
۷۱.۶۶۶	۸۶.۶۶۶	۶۶.۶۶۶	۶۶.۶۶۶	۶۶.۶۶۶	SVM
۷۵	۹۳.۳۳۳	۶۶.۶۶۶	۷۳.۳۳۳	۶۶.۶۶۶	M-Class (12 feature)
۸۰	۹۳.۳۳۳	۶۶.۶۶۶	۸۶.۶۶۶	۷۳.۳۳۳	M-Class (2 feature)

مراجع

- [1] MogensBlanke, Michel Kinnaert, Jan Lunze, and Marcel Staroswiecki, 'Diagnosis and Fault-Tolerant Control,' 2nd Edition, Springer-Verlag Berlin Heidelberg 2006.
- [2] Williams, T., Ribadeneira, X., Billington, S., Kurfess, T., "Rolling element bearing diagnostics in run-to-failure lifetime testing," Mechanical Systems and Signal Processing, v 15, n 5, Sept. 2001, 979-93.
- [3] Z.K. Peng, Peter W. Tse, F.L. Chu, 'A comparison study of improved Hilbert-Huang transform and wavelet transform: Application to fault diagnosis for rolling bearing,' Mechanical Systems and Signal Processing 19 (2005) 974-988.
- [4] Peng Z., Chu F., He Y., Vibration signal analysis and feature extraction based on re-assigned wavelet scalogram, Journal of Sound and Vibration 253 (5) 1087-1100, 2002.

جدول ۴: درصد خطای خروجی در کلاسیفایر با استفاده از ۱ ویژگی سیگنال

درصد خطای خروجی کاسیفایر	نوع ویژگی
۲۵	Moment(2)
۲۵	Moment(3)
۲۵	Cov(signal)
۲۵	Moment(5)
۲۵	Moment(6)
۳۰	Zcr(signal)
۴۳.۳۳۳	Pr(signal)
۲۱.۶۶۶	Kurtosis(signal)
۲۵	Std(signal)
۳۱.۶۶۶	Mean(signal)
۲۵	Max(abs(signal))
۶۳.۳۳۳	Skewness(signal)

نتایج بدست آمده از جدول ۴ نیز، گفته قبلی را اثبات نمود و نشان داد کلاسیفایر Multi Class SVM در کلاس بندی بسیار متاثر از ویژگی انتخاب شده می باشد.

در هر حال نیاز به ویژگی‌هایی با درصد تفکیک دهنده بالا وجود دارد و برای این منظور از روش‌های انتخاب ویژگی نظیر PCA استفاده شد. در نهایت بهترین عملکرد کلاسیفایر با انتخاب و استفاده از دو ویژگی Max(abs) و Kurtosis بدست آمد که نتایج آن در جدول ۵ ارائه شده است.

جدول ۵: خروجی کلاسیفایر پس از انتخاب و استفاده از دو ویژگی Kurtosis, Max(abs)

	BD	ORD	IRD	NB
BD	۱۱	۱	۰	۳
ORD	۰	۱۳	۰	۲
IRD	۰	۲	۱۰	۳
NB	۰	۱	۰	۱۴

۵- نتیجه گیری

در این مقاله سعی شد با دیدگاه Signal Based و ارائه یک کلاسیفایر جدید بر مبنای Multi Class SVM به بررسی تشخیص و شناسایی عیب در بیرینگ‌ها پرداخته شود. برای این منظور ابتدا به بررسی شرایط مختلف یک کاری یک بیرینگ و معرفی خطاهای رایج در آن پرداختیم و در بخش

- [20] M.L.Sin, W.L.Swong, N.Eartugrul, University of Adelaide, "Induction Machine Online Condition Monitoring and Fault Diagnosis-Survey in 2003."
- [21] J. Zarei, J. Poshtan, "Bearing fault detection using waveletpacket transform of induction motor stator current," *Journal of Tribology International*, Vol. 40(5), pp. 763-769, May 2007.
- [5] Yu Dejie, Cheng Junsheng, Yang Yu., 'Application of EMD method and Hilbert spectrum to the fault diagnosis of roller bearings,' *Mechanical Systems and Signal Processing* 19, 259–270, 2005.
- [6] V.K. Rai & A.R. Mohanty, 'Bearing fault diagnosis using FFT of intrinsic mode functions in Hilbert–Huang transform,' *Mechanical Systems and Signal Processing* 21, 2607–2615, 2007.
- [7] Cheng Junsheng, Yu Dejie, Yang Yu, 'A fault diagnosis approach for roller bearings based on EMD method and AR model,' *Mechanical Systems and Signal Processing* 20 (2006) 350–362.
- [8] Cheng Junsheng, Yu Dejie, Yang Yu, 'The envelope order spectrum based on generalized demodulation time–frequency analysis and its application to gear fault diagnosis,' *Mechanical Systems and Signal Processing* 24 (2010) 508–521.
- [9] Jin-II Park and Myung-Geun Chun, *Fault Diagnosis of Induction Motor using C-Fuzzy Model Tree and SVM*, ISIS 2007 .
- [10] J. Cheng, Y. Yang & D. Yu, "Application of support vector regression machines to the processing of end effects of Hilbert–Huang transform," *Mechanical Systems and Signal Processing* 21, 1197–1211, 2007.
- [11] R.B.W. Heng, M.J.M. Nor, *Statistical analysis of sound and vibration signals for monitoring rolling element bearing condition*, *Applied Acoustics* 53 (1998) 211–226.
- [12] F. Honarvar, H.R. Martin, *New statistical moments for diagnostics of rolling element bearings*, *Journal of Manufacturing Science and Engineering* 119 (1997) 425–432.
- [13] H.R. Martin, F. Honarvar, *Application of statistical moments to bearing failure detection*, *Applied Acoustics* 44(1995) 67–77.
- [14] Loparo, K. (2004). *Bearing fault diagnosis based on wavelet transform and fuzzy inference*. *Mechanical Systems and Signal Processing*, 18, 1077–1095.
- [15] Mallat, S. G. (1989). *IEEE Transactions on Pattern Analysis on Machine Intelligent*, 11–17, 674–693.
- [16] B. Yazici, G. B. Kliman, "An adaptive statistical time frequency method for detection of broken bars and bearing faults in motors," *IEEE Trans. On Industry App.*, vol. 35, no.2, March/April 1999.
- [17] S. Prabhakar, A. R. Mohanty, A. S Sekhar, "Application of discrete wavelet transform for detection of ball bearing race faults," *Journal of Tribology International*, vol. 35(12), pp.793-800 December 2002.
- [18] B.A. Paya, I.L. Esat, M.N.M. Madi, *Artificial neural network based fault diagnostics of rotating machinery using wavelet transforms as a processor*, *Mechanical Systems and Signal Processing* 11 (1997) 751–765.
- [19] Peter W. Tse, Y.H. Peng, Richard Yam, *Wavelet analysis and envelope detection for rolling element bearing – their affectivities and flexibilities*, *Journal of Vibration and Acoustic* 123 (2001) 303–310.